

量子遗传算法优化的 SVM 滚动轴承故障诊断*

许迪¹, 葛江华¹, 王亚萍¹, 卫芬², 邵俊鹏¹

(1. 哈尔滨理工大学机械动力工程学院 哈尔滨, 150080)

(2. 哈尔滨工业大学机电工程学院 哈尔滨, 150001)

摘要 针对单一测度模型的特征评价方法存在特征敏感度“欠学习”, 以及支持向量机(support vector machines, 简称 SVM)参数优化算法普遍存在收敛速度慢、易陷入局部极值等问题, 提出一种量子遗传算法优化的 SVM 滚动轴承故障诊断方法。首先, 采集振动信号中的时域和频域特征构成多域多类别原始故障特征集; 其次, 构建一个基于相关性、距离及信息等测度的混合特征评价模型, 得到特征权重与特征值组合构成的加权故障特征集; 最后, 将加权故障特征集为输入, 将量子熵引入到量子遗传算法当中, 对 SVM 的结构参数进行全局优化, 完成滚动轴承故障模式的识别。试验结果表明, 该方法能够以更快的速度收敛至全局最优解, 在保证聚类性能的基础上提高了滚动轴承的诊断精度。

关键词 特征敏感度; 混合特征评价; 量子遗传算法; 支持向量机; 滚动轴承故障诊断

中图分类号 TH165⁺.3; TP277

引言

滚动轴承作为旋转机械的关键部件之一, 其健康状态对整个机械设备的工作状态具有重要影响, 一旦发生故障将降低设备性能, 甚至导致灾难性后果^[1]。因此, 滚动轴承的状态监测与故障诊断成为保证机械设备正常工作及安全生产的重要环节。特征提取是故障诊断的关键, 通过对原始振动信号进行时域和频域分析, 提取反映故障特性的各项参数指标, 包括均值、方差、均方根值、峭度、峭度指标、脉冲指标、重心频率、频率均方根和频率峭度等, 这些特征参数已被广泛应用于滚动轴承故障诊断实际应用中^[2-3]。以上特征指标从不同侧面描述信号的不同特征, 但针对性较强、通用性偏弱, 难以全面描述复杂工况下的轴承故障信息。

现有的特征评价准则主要分为距离测度、相关性测度^[4]、信息测度^[5]及一致性测度^[6]等, 每种类别测度准则又包含若干特征评价模型。类间平均距、类内一类间综合距离及 Fisher 得分^[7]等属于距离测度的范畴。Pearson 相关系数属于一类相关性测度准则。信息增益(information gain)、最小描述长度(minimum description length)和互信息(mutual

information)等为基于信息测度的评价准则。拉普拉斯分值得(Laplacian score, 简称 LS)^[8]依据特征的局部信息保持能力和方差来进行特征评价。上述特征评价模型从不同侧面对特征进行评价, 具有一定的片面性。因此, 同时依据不同测度准则下的多种模型进行混合特征评价, 才能获得相对全面客观的评价结果。

在利用故障特征进行模式识别方面, SVM 能在样本数较少的情况下获得很好的分类推广能力, 与人工神经网络相比具有更好的泛化能力, 对小样本、非线性及高维模式识别等问题更具有适用性。然而, SVM 的分类性能受限于核函数参数及本身结构参数的选择, 这是 SVM 应用亟待解决的关键问题之一^[9-10]。为此, 学者们引入各种优化算法用于 SVM 参数的选择, 例如: 网格搜索算法、遗传算法和粒子群算法等^[11-12]。然而, 上述优化算法存在搜索效率低、收敛性差和易陷入局部极值等问题。量子遗传算法是一种基于量子计算原理的遗传算法, 是量子计算理论和遗传算法原理相结合的产物, 具有种群规模小、寻优能力强、收敛速度快和计算时间短等特点, 更适应于 SVM 参数的寻优。基于量子遗传算法(quantum genetic algorithm, 简称 QGA)优化 SVM 研究相关文献^[13-14]可知, 现有方法大都直

* 国家自然科学基金资助项目(51575143); 黑龙江省自然科学基金资助项目(E2016046)

收稿日期: 2017-10-30; 修回日期: 2018-01-29

接采用经典量子遗传算法实现 SVM 参数的优化,然而算法中基于固定步长旋转角调整策略的量子旋转门更新操作仍存在使寻优过程收敛速度变缓和陷入局部极值的风险。

笔者提出一种量子遗传算法优化的 SVM 滚动轴承故障诊断方法。利用一个综合距离、相关性和信息等测度的 10 种子评价模型组成的混合特征评价模型,对时频、频域特征参数组成的原始特征集进行特征敏感度学习,以各特征敏感度综合分值作为各特征权重组成新的加权特征集,并输入到改进的量子遗传算法优化的 SVM 模型中,完成对滚动轴承的故障诊断。

1 基于混合特征评价的敏感度学习

1.1 多域多类别故障特征提取

当滚动轴承出现故障时,其时域振动信号的幅值和概率分布会发生变化,信号中的频率成分、不同频谱的谱峰位置也将发生变化。因此,通过描述信号时域波形和频域波形分布等特征,可以反映振动信号的时域和频域信息,从而指示故障的出现。基于统计学理论的时域与频域特征具有物理意义明确、计算简单及实用性强等优点,被广泛应用于各类机械设备故障诊断中。笔者选择了 10 个时域特征 ($p_1 \sim p_{10}$, 依次为方差、标准差、均方根、峭度、裕度、波性指标、脉冲指标、峰值指标、裕度指标和峭度指标) 组成原始时域特征集,同时选择了 5 个频域特征 ($p_{11} \sim p_{15}$, 依次为均值频率、重心频率、均方根频率、标准差频率及峭度频率) 组成原始频域特征集。时域特征参数 p_1 反映时域振动能量大小; $p_2 \sim p_{10}$ 反映时域信号的时间序列分布情况。频域特征参数 p_{11} 反映频域振动能量大小; p_{12} 反映主频带位置的变化; $p_{13} \sim p_{15}$ 反映频谱的集中程度。

1.2 混合测度评价模型的建立

对包含多域多类别故障特征参量的高维特征集进行特征评价时,现阶段广泛应用的基于单一测度的评价模型仅从某一方面对特征进行敏感度学习,存在片面性,难以取得令人满意的特征评价效果。针对这一问题,笔者构建一个基于距离、相关性及信息等测度的混合特征评价模型,其中,基于每个测度基准选择若干种不同的特征评价模型,用于计算各特征的敏感度并求和。作为特征权重与原始特征值组合构成加权故障特征集,如图 1 所示。

选用 10 类典型特征评价模型作为各特征参数的子评价模型,即:数据方差、类间平均距、类内-类间综合距离、Fisher 得分、特征-类别间 Pearson 相关系数、特征间 Pearson 相关系数、综合 Pearson 相关系数、互信息、信息增益及拉普拉斯得分。统一定义一个由 n 个样本、 m 维特征参量组成的样本数据矩阵 $\mathbf{X} = (x_{ij})_{n \times m}$, x_{ij} 为第 i 个样本的第 j 维特征值, $i = 1, 2, \dots, n, j = 1, 2, \dots, m$ 。一个 $c \times 1$ 的表征样本类别标签的列向量 $\mathbf{Y} = [y_1, y_2, \dots, y_k]^T$, y_k 为第 k 个类别的样本标签, $k = 1, 2, \dots, c$ 。 x_{ij}^k 为第 k 类的第 i 个样本的第 j 个特征值。 μ_{kj} 为第 k 类样本的第 j 个特征的均值。 d_j^w 为样本集中 k 类样本的类内平均距离。 σ_{kj} 为第 k 类样本的第 j 个特征的方差。 $H(x_j)$ 为样本集中第 j 个特征样本信息熵, $H(Y)$ 为类别标签列向量的信息熵, $H(Y|x_j)$ 为条件熵。加权矩阵 \mathbf{S} 为样本近邻图 G 的相似矩阵,用来衡量近邻样本点之间的相似性。若 G 中节点 i 和节点 p 连通,则 $s_{ip} = \exp\left(-\frac{x_i - x_p}{t}\right)$; 否则, $s_{ip} = 0$ 。各子特征评价模型描述如表 1 所示。

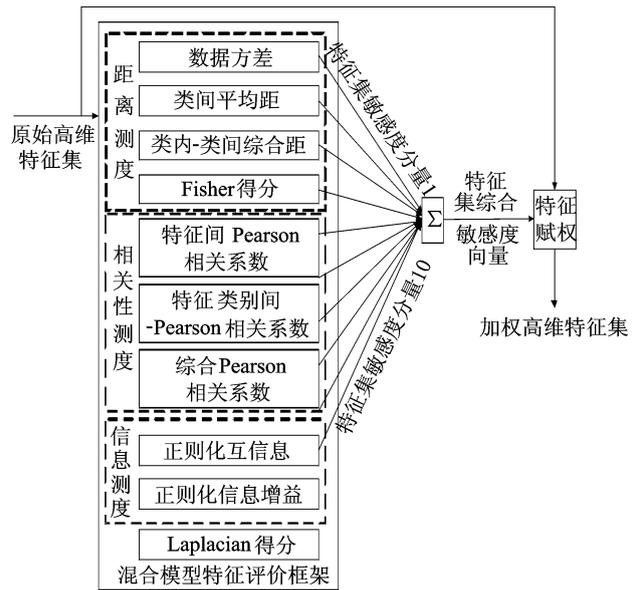


图 1 混合特征评价模型

Fig. 1 Flow chart of proposed feature weighting scheme

数据方差 FS_{1j} 作为一种最简单的特征评价模型,利用样本数据集中对应维特征的方差信息表征该特征的代表程度。某一特征的方差得分越高,代表该特征的敏感程度越强,因此直接以该分值作为特征的敏感度值。类别距离是不同类别样本可分性的一种重要判据,据此可将样本在某一特征上的类

别距离作为该特征对不同故障敏感程度的衡量标准。常用的类别距离主要有:类内平均距、类间平均距 FS_{2j} 及类内一类间综合距离 FS_{3j} 等。特征集中某一特征的 FS_{2j} 与 FS_{3j} 值越大,表明样本在该特征下的可分性越好,即该特征对不同故障的敏感程度越强。Fisher 得分 FS_{4j} 是一种可分性判别方法,通过计算特征的类间分离度与类内聚集度的比值作为该特征的敏感程度值。Pearson 相关系数是利用特征之间或特征与类标之间的相关性大小衡量单个特征对分类的贡献。平均 Pearson 相关系数 FS_{5j} 、与类别标签向量 \mathbf{Y} 的 Pearson 相关系数 FS_{6j} 及综合 Pearson 相关系数 FS_{7j} 综合利用特征之间及特征与

类标的相关性衡量特征的敏感程度。三类 Pearson 相关系数与特征敏感程度之间的关系是: FS_{5j} 越小、 FS_{6j} 越大或 FS_{7j} 越大,则该特征的敏感程度越高。正则化互信息 FS_{8j} 和信息增益 FS_{9j} 是两类典型的基于信息测度的特征评价模型,其基本思想是通过计算某一特征为分类带来的有用信息的大小来衡量特征对于分类的重要程度。 FS_{8j} 和 FS_{9j} 值越大,表明该特征的敏感程度越高。拉普拉斯分值 FS_{10j} 以拉普拉斯特征值映射和局部保持投影为基础,其基本思想是通过局部信息保持能力和方差信息来衡量特征。特征的 Laplacian 得分与其敏感程度成反比,得分值越低,该特征的敏感程度越高。

表 1 各特征参数子评价模型

Tab. 1 The evaluation model of feature parameter

评价指标	公式
数据方差 FS_{1j}	$\frac{1}{n} \sum_{i=1}^n (x_{ij} - \mu_j)^2$
类间平均距 FS_{2j}	$\frac{1}{c(c-1)} \sum_{\substack{k,e=1 \\ k \neq e}}^c \mu_{kj} - \mu_{ej} $
类内-类间综合距离 FS_{3j}	$\frac{1}{c} \sum_{k=1}^c \frac{1}{n(n-1)} \sum_{\substack{l=1 \\ l \neq i}}^n x_{ij}^k - x_{lj}^k $
Fisher 得分 FS_{4j}	$\frac{\sum_{k=1}^c n(\mu_{kj} - \mu_j)^2}{\sum_{k=1}^c n\sigma_{kj}^2}$
平均 Pearson 相关系数 FS_{5j}	$\frac{1}{m-1} \sum_{\substack{s=1 \\ s \neq j}}^m \left(\frac{\sum_{i=1}^n x_{ij} x_{is} \sum_{i=1}^n x_{is}}{\sum_{i=1}^n x_{ij} x_{is} \frac{\sum_{i=1}^n x_{is}}{n}} \right) \sqrt{\left(\frac{\sum_{i=1}^n x_{ij}^2}{n} \right) \left(\frac{\sum_{i=1}^n x_{is}^2}{n} \right)}$
类别标签向量 \mathbf{Y} 的 Pearson 相关系数 FS_{6j}	$\frac{\sum_{i=1}^n x_{ij} \sum_{k=1}^c y_k \frac{\sum_{i=1}^n x_{ij} \sum_{k=1}^c y_k}{n}}{\sqrt{\left(\sum_{i=1}^n x_{ij}^2 \frac{\sum_{i=1}^n x_{ij}}{n} \right) \left(\sum_{k=1}^c y_k^2 \frac{\sum_{k=1}^c y_k}{c} \right)}}$
综合 Pearson 相关系数 FS_{7j}	$\frac{FS_{6j}}{FS_{5j}}$
正则化互信息 FS_{8j}	$2 \frac{H(\mathbf{Y}) - H(\mathbf{Y} x_j)}{H(x_j) + H(\mathbf{Y})}$
信息增益 FS_{9j}	$\frac{FS_{8j}}{H(\mathbf{Y})}$
拉普拉斯分值 FS_{10j}	$\frac{\sum_{i,p=1}^n (x_{ij} - x_{pj})^2 s_{ip}}{\text{var}(x_j)}$

综合上述 10 种特征评价模型的得分,计算样本集中第 j 个特征的混合模型得分

$$HFS_j = \sum_{i=1}^4 FS_{ij} + \sum_{i=6}^9 FS_{ij} + \frac{1}{FS_{5j}} + \frac{1}{FS_{10j}} \quad (1)$$

则 m 个特征参数的敏感程度分值向量为 $\mathbf{s}_i = [HFS_1, HFS_2, \dots, HFS_i]$,构造一个行向量为 \mathbf{s}_i ,列数等于样本数 n 的权矩阵 \mathbf{S}_i ,将 \mathbf{S}_i 与原始特征矩阵 \mathbf{T}_i 相乘,得到对应的特征敏感程度加权矩阵 \mathbf{W}_i 。由式 (1) 可知,基于混合测度模型的特征敏感程度学习能够

综合全面地评价各特征,并以归一化后的综合得分值作为权值对原始特征集进行加权,进而得到加权特征集,作为后续分类任务的输入数据。

2 改进的量子遗传算法优化 SVM

在实际使用 SVM 时,其识别精度较大程度上受限于参数的选择。基于径向基核函数的 SVM 性能由参数 (C, σ) 决定,其中,参数 C 对 SVM 的影响是调节对错分样本的惩罚程度,是对经验风险与置信范围两者进行折中;核参数 σ 影响样本数据子空间分布的复杂程度,若 σ 选取不当,则会出现“过学习”或“欠学习”现象。因此,研究基于先进的参数选择方法的最优 SVM 模型获取是保证故障分类及诊断结果准确性的关键环节。

QGA 是一种新型概率进化算法,将量子的态矢量表达引入遗传编码,利用量子逻辑门实现染色体的演化,旨在克服经典遗传算法中因选择、交叉及变异方式不当引发的算法收敛速度缓慢、易陷入局部极值的局限性。算法建立在量子的态矢量表示的基础上,将量子比特的概率幅应用于染色体的编码中,使一条染色体可以表达多个态的叠加,并利用量子逻辑门实现染色体的更新操作,从而实现目标的优化求解。

量子比特(qubit)是量子计算机中充当信息存储单元的物理介质,其与经典比特的区别在于可同时处在两个量子态的叠加态中,即 $|\varphi\rangle = \alpha|0\rangle + \beta|1\rangle$,其中: α 和 β 为一对复常数,称为量子态的概率幅,且满足 $|\alpha|^2 + |\beta|^2 = 1$; $|0\rangle$ 和 $|1\rangle$ 分别表示自旋向下和自旋向上态。

在 QGA 中,采用量子比特存储和表达一个基因,该基因可以为“0”态或“1”态,或任意叠加态。采用量子比特编码使得一个染色体可同时表达多个态的叠加,使得 QGA 比经典遗传算法具有更好的种群多样性特征。

在量子计算中,量子门可以对量子位状态进行一系列变换以实现某些逻辑运算。量子门是 QGA 中演化操作的执行机构。常用的量子门有非门、受控非门、旋转门和 Hadamard 门等,以旋转门的应用最为广泛。基于旋转门的更新过程为

$$\begin{bmatrix} \alpha'_i \\ \beta'_i \end{bmatrix} = U(\theta_i) \begin{bmatrix} \alpha_i \\ \beta_i \end{bmatrix} = \begin{bmatrix} \cos(\theta_i) & -\sin(\theta_i) \\ \sin(\theta_i) & \cos(\theta_i) \end{bmatrix} \begin{bmatrix} \alpha_i \\ \beta_i \end{bmatrix} \quad (2)$$

其中: (α_i, β_i) 和 (α'_i, β'_i) 分别为染色体第 i 个量子比特旋转门更新前后的概率幅; $\theta_i = \Delta\theta_i s(\alpha_i, \beta_i)$ 为旋

转角; $\Delta\theta_i$ 为旋转的角度大小,用于确定收敛速度,在经典量子遗传算法(classical quantum genetic algorithm, 简称 CQGA)^[2] 中通常取某一固定值; $s(\alpha_i, \beta_i)$ 为旋转方向,以保证算法收敛,可由预先设定的通用的、与问题无关的调整策略确定。

考虑到固定步长的旋转角调整策略对算法寻优过程的影响,笔者提出了一种改进的量子遗传算法。采用新型基于量子熵的量子旋转角更新策略替换原有固定旋转角策略。

定义新型量子旋转角步长函数为

$$\Delta\theta_{ij} = \Delta\theta_{\min} + (\Delta\theta_{\max} - \Delta\theta_{\min}) \left(1 - \frac{t}{\text{MAXGEN}}\right) \cdot \exp\left(-\sum_{q_i \in Q_t} \mathbf{H}(q_i, t)\right) \quad (3)$$

其中: $\Delta\theta_{ij}$ 为第 i 个染色体中第 j 个量子位旋转角步长; $\Delta\theta_{\max}$ 和 $\Delta\theta_{\min}$ 分别为旋转角的最大值和最小值; t 为当前进化代数;MAXGEN 为最大进化代数; Q_t 为第 t 代染色体种群; q_i 为种群中任意个体; $\mathbf{H}(q_i, t) = \sum_{i=1}^m \sqrt{|\alpha_i^2 - \beta_i^2|}$ 为第 t 代种群的熵,反映量子比特的不确定状态。

随着种群的进化, $|\alpha^2|$ 和 $|\beta^2|$ 逐渐趋于 0 或 1,进化过程是种群从不平衡状态到平衡状态的转变,可根据种群的量子熵判断种群的收敛和聚集状态。可见,量子熵的计算在反映种群收敛信息的同时,避免了复杂的目标函数信息计算,节省了算法的计算时间。

通过式(3)所示旋转角更新操作,旋转角的方向 $s(\alpha_i, \beta_i)$ 根据 CQGA 中设定的调整策略执行,即为新型量子旋转门操作算子 $U'(t)$ 。量子遗传算法优化的 SVM 参数寻优步骤如下。

1) 设置算法基本参数,包括群体规模 N ,最大迭代次数 T 、每个变量的二进制长度 L 及待优化参数 C 和 σ 的取值区间 $[C_{\min}, C_{\max}]$ 与 $[\sigma_{\min}, \sigma_{\max}]$ 。

2) 种群初始化,设定量子种群为 $Q(t) = \{q_1^t, q_2^t, \dots, q_N^t\}$ 。其中: t 为当前遗传代数; q_i^t 为种群个体的一条染色体,定义 $q_i^t = \begin{bmatrix} \alpha_{Ci}^t \\ \beta_{Ci}^t \end{bmatrix}$; $(\alpha_{Ci}^t, \beta_{Ci}^t)$ 和 $(\alpha_{\sigma i}^t, \beta_{\sigma i}^t)$ 分别为待优化参数 C 和 σ 的量子位。将 $Q(t)$ 初始化得到 $Q(t_0)$,设定全部染色体的概率幅均为 $\frac{1}{\sqrt{2}}$ 。

3) 对初始种群 $Q(t_0)$ 中的每个个体进行一次测量,生成二进制解集 $P(t_0)$ 。

4) 对 $P(t_0)$ 中的各确定解进行适应度评估,以交叉验证正确率作为个体的适应值来反映 SVM 的分类能力。适应度函数公式为 $\text{Fitness} = S_{\text{cor}}/S \times$

100%,其中: S_{cor} 为正确分类的样本数; S 为总样本数,记录最优个体和对应的适应度值。

5) 判断是否满足终止条件,若满足则终止,否则继续执行下一步。

6) 对种群 $Q(t)$ 中各个体进行一次测量,生成二进制解集 $P(t)$,并对各确定解进行适应度评估。

7) 利用新型量子旋转门 $U'(t)$ 对个体实施调整,得到新的种群 $Q(t+1)$,通过测量 $Q(t+1)$ 中的每个个体得到 $P(t+1)$,在对各确定解进行适应度评估的基础上记录最优个体和对应的适应度值。

8) 将迭代次数加 1,返回步骤 5。

3 滚动轴承故障诊断流程

量子遗传算法优化的 SVM 滚动轴承故障诊断实现过程如图 2 所示,主要诊断步骤如下。

1) 对滚动轴承故障振动信号进行时域与频域统计分析,构建 1×15 维多域多类别故障特征向量 $T = \{p_1, p_2, \dots, p_{15}\}$ 。

2) 利用多特征评价的敏感度学习模型对原始故障特征集 T 中的各特征参量 p_i 进行评价,得到各特征的综合敏感度值 HFS_i ,并以此作为对应特征权重与特征值组合构成加权故障特征集 W_i 。

3) 利用改进量子遗传优化算法对 SVM 分类器模型中的参数 (C, σ) 进行寻优,利用优化过程得到的最优参数 (C, σ) 值获得最优 SVM 模型,将步骤 2 中的加权故障特征集输入到该最优 SVM 分类器,完成滚动轴承的故障诊断。

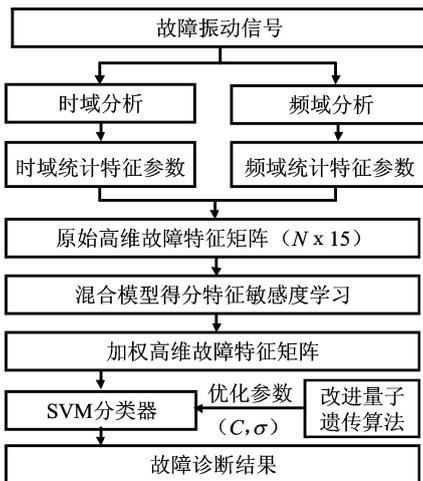


图 2 滚动轴承故障诊断流程

Fig. 2 Flow chart of fault diagnosis model

4 试验验证与分析

为了评价本研究方法的有效性,利用两组不同

的实测滚动轴承故障振动数据对其进行验证。两组试验数据的描述如下。

试验 I 的数据来源于美国凯斯西储大学电气工程滚动轴承试验平台,如图 3 所示^[15]。测试轴承型号为 6025-2RS JEM SKF 深沟球轴承,试验台主轴转速为 1 750r/min,电机负载为 1.49kW。试验采用电火花加工技术在轴承内圈、外圈及滚动体上分别加工一个不同直径的单点故障,用于实现不用故障类型、不同故障程度的轴承单点点蚀故障。轴承故障振动信号由安装在轴承座上的加速度传感器获取,信号采样频率为 12 kHz。

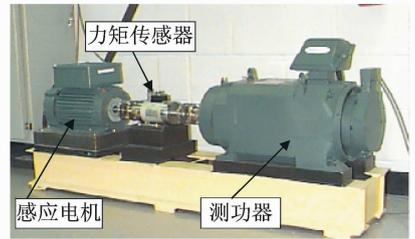


图 3 轴承故障模拟试验平台(数据 I)

Fig. 3 Rolling element bearing fault simulation experiment (case I)

表 2 滚动轴承故障试验数据描述

Tab. 2 Fault experiment data description of rolling bearing

故障类型	故障大小 (mm×mm)	故障程度	简称	类别 标号
正常	0	无	Normal	1
滚动体故障	0.177 8×0.279 4	轻微	B/0.007	2
滚动体故障	0.355 6×0.279 4	中度	B/0.014	3
滚动体故障	0.533 4×0.279 4	严重	B/0.021	4
内圈故障	0.177 8×0.279 4	轻微	IR/0.007	5
内圈故障	0.355 6×0.279 4	中度	IR/0.014	6
内圈故障	0.533 4×0.279 4	严重	IR/0.021	7
外圈故障	0.177 8×0.279 4	轻微	OR/0.007	8
外圈故障	0.355 6×0.279 4	中度	OR/0.014	9
外圈故障	0.533 4×0.279 4	严重	OR/0.021	10

试验 II 的数据来自于澳大利亚新南威尔士大学 Sweeney 博士搭建的单级直齿齿轮箱试验平台,如图 4 所示^[16]。被测轴承类型为双列球轴承,主轴转速为 6Hz,轴承故障振动信号由安装在被测轴承上端齿轮箱壳体上的振动加速度传感器测得,信号的采样频率为 48 kHz。试验过程中模拟了 4 种轴承状态分别是:正常状态、内圈故障、外圈故障及滚动体故障。其中:正常、内外圈的故障尺寸是宽为 0.8mm,深为 0.3mm 的槽口故障;滚动体的故障尺

寸是宽为0.5mm,深为0.5mm的缺口故障。

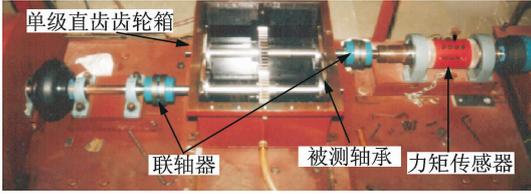


图4 直齿齿轮箱试验平台(数据II)

Fig. 4 Schematic diagram of gearbox fault simulation experiment (case II)

针对两组试验数据,均设定其单个样本数据长度为2 048,每种状态各取50组样本,以其中的30组作为训练样本,剩余的20组作为测试样本。

表3 主要原始特征评价指标与加权指标

Tab. 3 The part of original features evaluation and weighted index

原始特征	评价指标										S_1	W_1
	FS_{1j}	FS_{2j}	FS_{3j}	FS_{4j}	FS_{5j}	FS_{6j}	FS_{7j}	FS_{8j}	FS_{9j}	FS_{10j}		
p_1	0.014	0.658	0.068	0.044	0.137	95.258	3.433	1.897	0.011	2.624	0.615	0.216
p_2	0.036	0.654	0.065	0.043	0.223	110.875	6.142	1.897	0.011	6.296	1.255	6.646
p_3	0.036	0.653	0.065	0.043	0.223	111.011	6.143	1.897	0.011	6.290	1.254	6.689
p_4	0.021	0.099	0.236	0.023	0.168	8.373	31.210	1.897	0.011	33.801	0.007	0.093
p_5	35.402	0.501	0.093	0.046	6.559	30.561	298.493	1.897	0.011	153.249	0.048	10.163

和 T_2 相乘,得到两组试验数据对应的基于特征敏感度的加权特征矩阵 W_1 和 W_2 。为了能够更加明显地区分滚动轴承不同的故障类别,对原始特征矩阵进行敏感度加权,实现可视化分析。分别利用核主成分分析(kernel principal component analysis,简称KPCA)对原始特征矩阵 T_1 , T_2 和加权特征矩阵 W_1 , W_2 进行维数约简,得到两组试验数据加权前后的KPCA三维输出结果,如图5和图6所示。对比图5,图6可知,对于两组不同的试验数据,其加权特征样本的区分效果明显优于原始未加权特征样本,不仅使各类型故障样本数据的类内聚集更为集中,而且改善了不同类样本的重叠问题。因此,对原始特征样本进行基于混合模型的特征敏感度加权能够有效提高多类别滚动轴承故障特征的分类性能。

为进一步验证混合加权特征模型对样本分类性能的提升效果,针对两组试验数据,分别将基于混合模型得分特征敏感度加权特征矩阵(M_0)、10种基于单一模型得分特征敏感度加权特征矩阵($M_1 \sim M_{10}$)及原始未加权特征矩阵(M_{11})输入SVM分类器进行故障识别,SVM模型参数设置为: $C=2, \sigma=1$ 。

对每组试验中每类的每个样本数据进行时域、频域分析,构建特征向量 $T = \{p_1, p_2, \dots, p_{15}\}$,分别依据两组试验数据中样本个数构造两个不同维度的原始特征矩阵 $T_1 \in R^{500 \times 15}$ 和 $T_2 \in R^{200 \times 15}$ 。具有代表性的原始特征评价指标与加权指标如表3所示。

由表3可知,加权后的特征参数区别更加明显,且 S_2, W_2 的加权方式与 S_1, W_1 相同。首先,采用混合特征评价模型分别对矩阵 T_1 和 T_2 的各列向量对应的特征参数进行打分,得到对应于两个矩阵特征参数的敏感度分值向量 $s_1 = [HFS_1, HFS_2, \dots, HFS_{15}]$ 和 s_2 ,进而分别构造一个行向量均为 s_1 或 s_2 ,且行数等于样本数的权矩阵 S_1 和 S_2 。将 S_1 和 S_2 分别与各自的原始特征矩阵 T_1

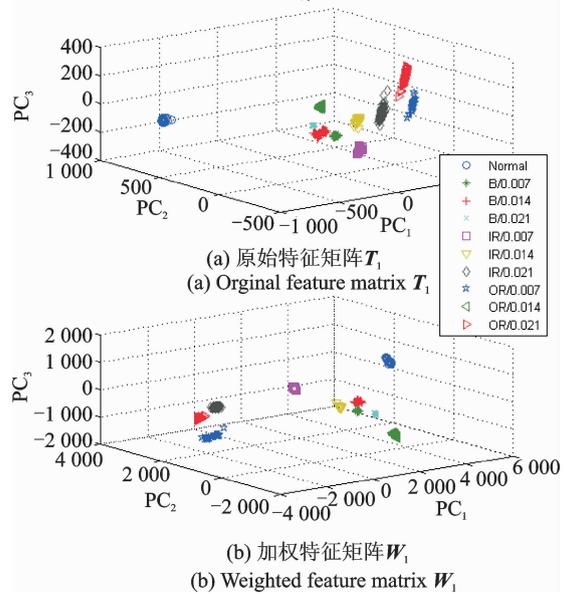


图5 试验数据1的加权前后特征矩阵的KPCA结果
Fig. 5 3-D scatter plots distribution diagrams of two different feature sets based on KPCA in case I

两组试验结果如图7所示。由图7可知,以特征集

中各特征参数的敏感度为权重对原始特征矩阵赋权,构成的加权特征矩阵具有比原始特征矩阵更高的分类精度,混合加权特征模型克服了传统单一模型评价的片面性,能够获得最高的分类精度。

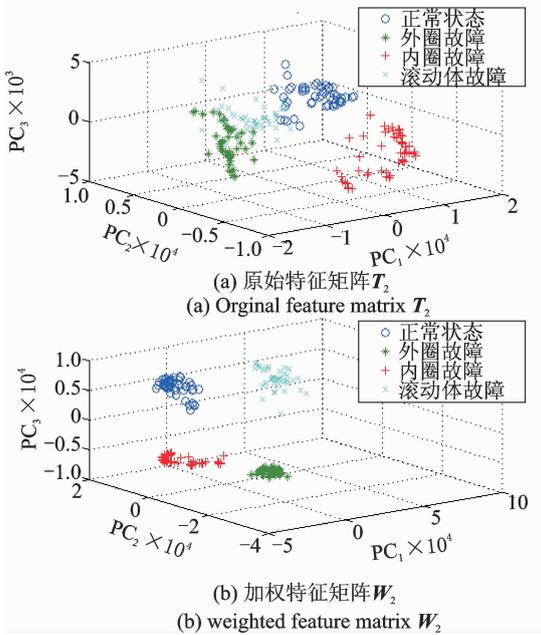


图 6 试验数据 2 加权前后特征矩阵的 KPCA 结果
Fig. 6 3-D scatter plots distribution diagrams of two different feature sets based on KPCA in case II

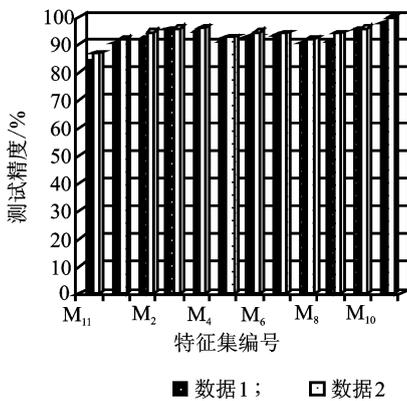


图 7 不同类型的样本特征矩阵的 SVM 分类结果
Fig. 7 Classification results of different feature matrix based on SVM

以两组试验数据中未加权原始特征矩阵为输入,验证笔者提出的基于改进量子遗传算法(improved quantum genetic algorithm, 简称 IQGA)的 SVM 参数优化方法的有效性,并与基于 CQGA,遗传算法(genetic algorithm, 简称 GA)的 SVM 优化过程进行对比分析。3 类算法的种群数均设为 10,最大进化代数设为 100。IQGA 与 CQGA 中,量子

位数目设为 2,量子观测态采用 20 位二进制数表示,IQGA 中旋转角取值区间设置为 $[0, 0.05\pi, 0.05\pi]$ 。GA 中变异概率为 0.1,交叉概率为 0.9。待优化参数 C 和 σ 的取值区间均为 $[0, 100]$ 。针对两组试验数据,基于 3 类算法的 SVM 参数寻优过程分别如图 8 和图 9 所示。由图 8 可知,对于第 1 组滚动轴承试验数据,在 SVM 参数寻优的过程中,笔者提出的 IQGA 无论是在收敛速度还是在收敛精度上明显优于 CQGA 以及 GA。相似的结论同样可由图 9 得出,即对于第 2 组数据而言,相比于 CQGA 和 GA,基于 IQGA 优化的 SVM 以最快的速度收敛于 100% 的最优适应度值。上述结果证明了基于量子熵的 IQGA 在 SVM 参数寻优中表现出的高于 CQGA 以及 GA 的技术优势。此外,由试验结果可知,IQGA 与 CQGA 均表现出在 SVM 参数选择中优于传统的 GA 的收敛性能,证明了相比于现有寻优算法,QGA 及其衍生出的 IQGA 更加适用于 SVM 模型的寻优。

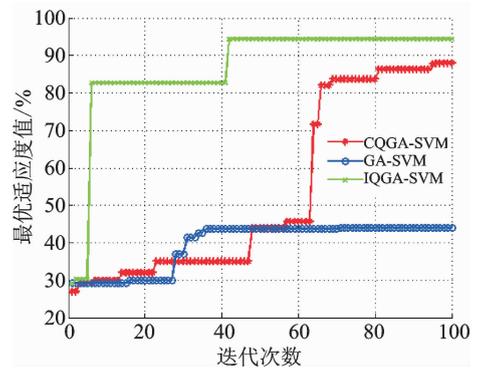


图 8 基于 3 类不同进化算法的 SVM 优化过程(试验数据 1)
Fig. 8 The Iteration result of three different SVM parameters optimization for case I

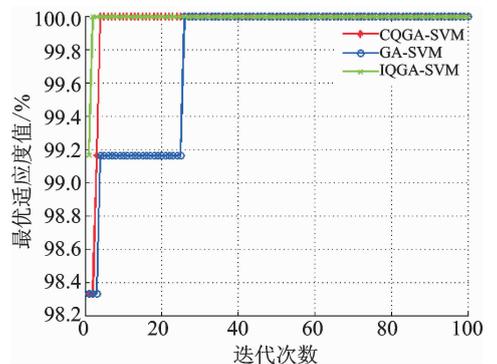


图 9 基于 3 类不同进化算法的 SVM 优化过程(试验数据 2)
Fig. 9 The Iteration result of three different SVM parameters optimization for case II

为进一步评价笔者提出的基于混合模型得分的加权特征集 (hybrid feature set, 简称 HFS) 与 IQGA 优化的 SVM (IQGA-SVM) 结合的滚动轴承故障诊断模型的优越性, 将本研究方法与基于混合模型得分加权特征集与固定参数 SVM 的诊断模型、基于原始特征集 (original feature set, 简称 OFS) 与

IQGA 优化 SVM 的诊断模型及基于原始特征集与固定参数 SVM 的诊断模型分别在前述两组试验数据上进行对比。固定参数 SVM 模型中, 参数 C 和 σ 的取值分别为 2 和 1。针对两组不同试验数据, 上述 4 种诊断模型的未正确识别样本的累计总数、分布情况及总体测试精度分别如表 4 和表 5 所示。

表 4 4 种不同故障诊断模型的分类结果 (试验数据 I)

Tab. 4 Classification results of four different fault diagnosis models (case I)

诊断模型	未正确识别样本 累积总数	正常	滚动体			内圈			外圈			测试精度/%
			轻微	中度	严重	轻微	中度	严重	轻微	中度	严重	
OFS+SVM	34	2	1	8	4	7	8	3	0	0	1	83
OFS+(IQGA-SVM)	9	0	1	2	0	3	1	0	1	1	0	95.5
HFS+ SVM	4	1	0	0	0	0	0	1	0	2	0	98
HFS+(IQGA-SVM)	1	0	0	0	0	0	0	0	0	1	0	99.5

表 5 4 种不同故障诊断模型的分类结果 (对于试验数据 II)

Tab. 5 Classification results of four different fault diagnosis models (case II)

诊断模型	未正确识别样本累积总数	正常	滚动体	内圈	外圈	测试精度/%
OFS+SVM	12	0	4	8	0	85
OFS+(IQGA-SVM)	7	0	4	3	0	91.25
HFS+ SVM	3	0	0	0	3	95
HFS+(IQGA-SVM)	0	0	0	0	0	100

对于两组不同试验数据, 诊断模型的测试精度分别达到 99.5% 和 100%, 相比于基于 HFS+SVM 的诊断模型、基于 OFS+(IQGA-SVM) 的诊断模型及基于 OFS+SVM 的诊断模型分别提高了 1.5% (5%), 4% (8.75%) 和 16.5% (15%)。其中, 两类基于混合模型得分加权特征集的诊断模型的测试精度高于另两类基于原始特征集的测试精度, 再一次证明了对原始故障特征集进行基于特征敏感度加权的方法的技术优势, 另一方面, 两类基于 IQGA 优化 SVM 分类器的测试精度同样高于另两类基于固定参数 SVM 分类器的测试精度, 由此证明了利用 IQGA 优化得到的 SVM 模型的性能明显优于传统的固定参数 SVM 模型。

5 结束语

提出了一种量子遗传算法优化的 SVM 滚动轴承故障诊断方法, 建立了集相关性、距离及信息于一体的混合特征评价模型, 解决了从单一测度对故障特征参数的敏感度学习评价模型存在的信息丢失的问题。利用量子熵对 CQGA 中固定旋转角调整策

略进行了修正, 并引入到 SVM 分类模型的参数优化中。解决了 SVM 分类器传统的优化算法存在收敛速度缓慢、易陷入局部极值的问题。结果表明, 该方法在提高分类精度的基础上, 能够更加精准地诊断滚动轴承的故障类型, 为滚动轴承健康维修奠定理论基础。

参 考 文 献

- [1] 王亚萍, 许迪, 葛江华, 等. 基于 SPWVD 时频图纹理特征的滚动轴承故障诊断[J]. 振动、测试与诊断, 2017, 37(1): 115-119.
Wang Yaping, Xu Di, Ge Jianghua, et al. Rolling bearing faults diagnostics based on SPWVD time-frequency distribution image texture feature[J]. Journal of Vibration, Measurement & Diagnosis, 2017, 37 (1): 115-119. (in Chinese)
- [2] Randall R B, Antoni J. Rolling element bearing diagnostics-a tutorial [J]. Mechanical Systems and Signal Processing, 2011 (25): 485-520.
- [3] Lei Yaguo, He Zhengjia, Zi Yanyang. A new approach to intelligent fault diagnosis of rotating machin-

- ery [J]. *Expert Systems with Applications*, 2008 (35):1593-1600.
- [4] Guyon I, Elisseeff A. An introduction to variable and feature selection [J]. *Journal of Machine Learning Research*, 2003(3): 1157-1182.
- [5] Liu Huan, Yu Lei. Toward integrating feature selection algorithms for classification and clustering [J]. *IEEE Transactions on Knowledge and Data Engineering*, 2005 (17): 491-502.
- [6] Dash M, Liu H. Consistency-based search in feature selection [J]. *Artificial Intelligence*, 2003, 151(16): 155-176.
- [7] Gu Quanquan, Li Zhenhui, Han Jiawei. Generalized fisher score for feature selection [C] // *Proceeding of the 27th Annual Conference on Uncertainty in Artificial Intelligence*. Barcelona, MA: AUAI Press, 2011: 266-273.
- [8] He Xiaofei, Cai Deng, Niyogi P. Laplacian score for feature selection [C] // *Neural Information Processing System*. Cambridge, MA: MIT Press, 2006: 507-514.
- [9] Chen Fafa, Tang Baoping, Song Tao, et al. Multi-fault diagnosis study on roller bearing based on multi-kernel support vector machine with chaotic particle swarm optimization [J]. *Measurement*, 2014 (47): 576-590.
- [10] 雷亚国, 陈昊, 李乃鹏, 等. 自适应多核组合相关向量机预测方法及其在机械设备剩余寿命预测中的应用 [J]. *机械工程学报*, 2016, 52(1):87-93.
Lei Yaguo, Chen Wu, Li Naipeng, et al. A relevance vector machine prediction method based on adaptive multi-kernel combination and its application to remaining useful life prediction of machinery [J]. *Journal of Mechanical Engineering*, 2016, 52 (1): 87-93. (in Chinese)
- [11] Bordoloi D J, Tiwari R. Support vector machine based optimization of multi-fault classification of gears with evolutionary algorithms from time-frequency vibration data [J]. *Measurement*, 2014(55):1-14.
- [12] 康守强, 王玉静, 崔历历, 等. 基于CFOA-MKHSVM的滚动轴承健康状态评估方法 [J]. *仪器仪表学报*, 2016, 37(9): 2029-2035.
- Kang Shouqiang, Wang Yujing, Cui Lili, et al. Health state assessment of a rolling bearing based on CFOA-MKHSVM method [J]. *Chinese Journal of Scientific Instrument*, 2016, 37(9): 2029-2035. (in Chinese)
- [13] Liu Zhiwen, Cao Hongrui, Chen Xuefeng, et al. Multi-fault classification based on wavelet SVM with PSO algorithm to analyze vibration signals from rolling element bearings [J]. *Neurocomputing*, 2013 (99): 399-410.
- [14] 王波, 刘树林, 蒋超, 等. 基于量子遗传算法优化RVM的滚动轴承智能故障诊断 [J]. *振动与冲击*, 2015, 34(17): 207-212.
Wang Bo, Liu Shulin, Jiang Chao, et al. Rolling bearings' intelligent fault diagnosis based on RVM optimized with quantum genetic algorithm [J]. *Journal of Vibration and Shock*, 2015, 34(17):207-212. (in Chinese)
- [15] Loparo K A. Case western reserve university bearing data center [EB/OL]. [2017-09-10]. <http://www.eecs.cwru.edu/laboratory/bearing/download>
- [16] Sawalhi N, Randall R B. Simulating gear and bearing interactions in the presence of faults part I, the combined gear bearing dynamic model and the simulation of localised bearing faults [J]. *Mechanical System and Signal Processing*, 2008, 22 (8): 1924-1951.



第一作者简介:许迪,女,1991年11月生,博士生。主要研究方向为旋转机械故障检测、性能衰退预测等。曾发表《基于SPWVD时频图纹理特征的滚动轴承故障诊断》(《振动、测试与诊断》2017年第37卷第1期)等论文。

E-mail: 15114642186@163.com

通信作者简介:葛江华,女,1963年6月生,博士、教授。主要研究方向为旋转机械设备健康管理及监测。

E-mail: gejianghua@sina.com

